



별첨 사본은 아래 출원의 원본과 동일함을 증명함.

This is to certify that the following application annexed hereto is a true copy from the records of the Korean Intellectual Property Office.

출원번호 : 10-2003-0052682
Application Number

출원년월일 : 2003년 07월 30일
Date of Application JUL 30, 2003


출원인 : 주식회사 팬택
Applicant(s) PANTECH CO., LTD.



2003 년 12 월 04 일

특 허 청

COMMISSIONER



【서지사항】

【서류명】	특허출원서		
【권리구분】	특허		
【수신처】	특허청장		
【제출일자】	2003.07.30		
【발명의 명칭】	상태 확률 보정 방법		
【발명의 영문명칭】	METHOD FOR MODIFICATING STATE		
【출원인】			
【명칭】	주식회사 팬택		
【출원인코드】	1-1998-004053-1		
【대리인】			
【명칭】	특허법인 신성		
【대리인코드】	9-2000-100004-8		
【지정된변리사】	변리사 신윤정, 변리사 원석희, 변리사 박해천		
【포괄위임등록번호】	2002-089790-8		
【발명자】			
【성명의 국문표기】	권태희		
【성명의 영문표기】	KWON, Tae Hee		
【주민등록번호】	751030-1496210		
【우편번호】	570-080		
【주소】	전라북도 익산시 송학동 현대아파트 105-303		
【국적】	KR		
【공지에외적용대상증명서류의 내용】			
【공개형태】	간행물 발표		
【공개일자】	2003.06.02		
【심사청구】	청구		
【취지】	특허법 제42조의 규정에 의한 출원, 특허법 제60조의 규정에 의한 출원심사를 청구합니다. 대리인 특허법인 신성 (인)		
【수수료】			
【기본출원료】	20	면	29,000 원
【가산출원료】	2	면	2,000 원

【우선권주장료】	0	건	0	원
【심사청구료】	6	항	301,000	원
【합계】	332,000			원
【첨부서류】	1. 요약서·명세서(도면)_1통 2. 공지에외적용대상(신규성상실의예 외, 출원시의특례)규정을 적용받 기 위한 증명서류_1통			

【요약서】

【요약】

본 발명의 상태 확률 보정 방법은, 훈련 데이터에 대한 인식 오류를 감소시키기 위하여 음성 인식 단위 집합을 구성하는 각각의 HMM의 상태에 대응하는 가중치를 도입하고 이를 훈련하는 과정에 있어서 발생하는 훈련 데이터에 대한 과적응 문제를 해결하기 위해서 확장된 손실 함수를 도입하여 상태 가중치를 훈련함으로써 훈련 데이터에 대한 과적응 문제를 완화시킴으로써 훈련 데이터 및 인식 데이터에 대한 음성 인식 성능 향상을 도모할 수 있는 상태 확률 보정 방법을 제공하는데 그 목적이 있다.

상기 목적을 달성하기 위하여 본 발명은, 분별함수를 통하여 입력되는 음성의 패턴을 인식하는 단계; 입력 음성에 대하여 클래스를 결정하는 단계; 상기 클래스의 결정에 따른 음성 인식 성능을 나타내는 평균손실함수를 획득하는 단계; 상기 평균손실함수에 의해 모델 파라미터를 도출하는 단계; 및 상기 모델 파라미터 식에 따라 상태 가중치 훈련을 수행하는 단계를 포함하고, 상기 분별함수는 각 클래스에서 시간에 대한 최적 상태의 가중치를 상기 분별함수 내 확률 밀도 성분에 적용하는 것을 특징으로 한다.

【대표도】

도 1

【색인어】

상태 가중치, 클래스, 음성 인식, 분별 함수

【명세서】**【발명의 명칭】**

상태 확률 보정 방법{METHOD FOR MODIFICATING STATE}

【도면의 간단한 설명】

도 1은 본 발명의 일 실시예에 의한 상태 확률 보정 방법을 나타낸 동작흐름도,
도 2는 SIG를 이용한 상태 가중치 훈련을 나타낸 그래프,
도 3은 SIG+WL을 이용한 상태 가중치 훈련을 나타낸 그래프,
도 4는 LIN을 이용한 상태 가중치 훈련을 나타낸 그래프,
도 5는 LIN+WL을 이용한 상태 가중치 훈련을 나타낸 그래프.

【발명의 상세한 설명】**【발명의 목적】****【발명이 속하는 기술분야 및 그 분야의 종래기술】**

<6> 본 발명은 상태 확률 보정 방법에 관한 것으로, 특히, MCE 훈련 과정에 있어서 상태 가중치의 훈련 데이터에 대한 과적응을 방지하기 위하여 확장된 오인식 척도를 사용하여 상태 가중치를 훈련시킴으로써 음성 인식 성능 향상을 도모하는 확정된 손실 함수를 이용한 상태 확률 보정 방법에 관한 것이다.

<7> 일반적으로, 은닉 마코프 모델링(Hidden Markov Modeling)은 음성 인식에서 음성의 특징을 표현하는데 매우 널리 사용되고 있다. 은닉 마코프 모델링은 통계적인 기반 위에서 음성의

특징을 모델링하는 일을 HMM 상태의 확률 분포 추정 방법으로 귀결시킨다. 이러한 상태 확률 분포 추정 방법으로써 가장 널리 사용되는 방법은 ML(Maximum Likelihood) 추정 방법이다.

<8> 그러나, ML 추정 방법은 훈련 데이터의 확률 분포에 대한 정확한 정보를 알아내는 일이 매우 어려우며 유사 음성들 사이의 구분되는 정보를 모델링하기가 거의 불가능하다. 패턴 인식 문제에서 위와 같은 확률 분포 추정의 단점을 보완하기 위한 방법으로 분별 훈련 방법이 많이 연구되어 왔다.

<9> 특히, 음성 인식기의 성능은 인식기의 평균 인식 에러율로 정의되며 최적 인식기는 최소의 인식 에러율을 나타내는 인식기이다. 이러한 관점에서 주로 연구되어 온 분별 훈련 기법이 GPD(Generalized Probabilistic Descent) 알고리즘에 기반한 MCE(Minimum Classification Error) 훈련 방법이다.

<10> MCE 훈련 기법의 목적은 데이터의 확률 분포를 추정하여 모델을 얻는 것이 아니고 최고의 인식 결과를 위해서 HMM의 관측 데이터를 구분하는 것이다. 이하 MCE 알고리즘을 간략히 설명하고 에러 확률의 합리적인 추정치를 나타내는 최적화 범주에 대하여 논의한다. 또한, MCE 훈련 방법은 궁극적으로 인식 오류의 최소화 관점에서 접근하며 특징 추출, 음향 모델링 기법, 음향 모델의 정밀도가 고정된 상태에서 믹스처(mixture) 가중치, 평균, 표준편차 등의 HMM 기본 파라미터들을 조절해 줌으로써 음성 인식의 성능 향상을 달성할 수 있음이 이미 연구되어 왔다. MCE 훈련 방법의 확장된 방법으로써 HMM 상태 확률에 내재해 있는 음성들 사이의 구분되는 정보를 이용하여 인식기를 최적화하기 위해서 상태 가중치를 도입하는 방법이 연구되었다. MCE 훈련 기법은 주로 ML 훈련 기법과 병행하여 행해지고 있으며 ML 훈련 방법에 의해 추정된 HMM보다 우수한 성능을 보인다.

<11> 기본적인 HMM 기반의 음성 인식기에서, 패턴 인식을 위해 클래스 i 에 대한 분별 함수는 다음 식과 같이 정의된다.

<12>

$$g_i(\mathbf{X}; \Lambda) = \sum_{t=1}^T \left[\log a_{\bar{q}_{t-1}\bar{q}_t}^{(i)} + \log b_{\bar{q}_t}^{(i)}(\mathbf{x}_t) \right] + \log \pi_{\bar{q}_0}^{(i)}$$

【수학식 1】

<13> 여기에서, $\bar{\mathbf{q}} = (\bar{q}_0, \bar{q}_1, \Lambda, \bar{q}_T)$ 는, 클래스 i 에 대해 조인트 상태열-관측열 확률 함수를 최대화하는 최적의 상태열이고, a_{ij} 는 상태 i 에서 상태 j 로 천이하는 상태 천이 확률을 의미한다.

<14> $b_j(\mathbf{x}_t)$ 는 상태 j 에서 관측벡터 \mathbf{x}_t 를 관측하는 확률 밀도 함수를 나타낸다. 연속적인 다변수 믹스처(mixture) 가우시안 HMM에서는, 상태 출력 분포는 다음과 같다.

<15>

$$b_j(\mathbf{x}_t) = \sum_{m=1}^M c_{jm} N(\mathbf{x}_t; \boldsymbol{\mu}_{jm}, \boldsymbol{\Sigma}_{jm})$$

【수학식 2】

<16> 여기에서, $N(\cdot)$ 은 다변수 가우시안 밀도 함수를 표기하며 $\boldsymbol{\mu}_{jm}$ 는 상태 j , 믹스처(mixture) m 에서의 평균 벡터이고, $\boldsymbol{\Sigma}_{jm}$ 는 상태 j , 믹스처(mixture) m 에서의 상관행렬이다.

<17> 입력 음성에 대하여, 클래스 결정 규칙이 사용되며 입력 음성 \mathbf{X} 에 대한 클래스 $C(\mathbf{X})$ 는 다음과 같은 규칙에 의해 결정된다.

<18>

$$C(\mathbf{X}) = C_i \quad \text{if } i = \arg \max_j g_j(\mathbf{X}; \Lambda)$$

【수학식 3】

<19> 여기에서, C_i 는 분별함수에 의해 입력 음성 또는 관측 벡터열에 대해 결정된 클래스를 의미한다.

<20> 먼저, 연산적인 결정 규칙인 수학식 3을 함수 형태로 표현하는 것이 필요하다. 패턴 인식기의 파라미터 세트 Λ 의 연속적인 함수로서 결정 규칙을 함축하는 클래스 오인식 척도는 다음과 같이 정의된다.

<21>

$$d_i(\mathbf{X}; \Lambda) = -g_i(\mathbf{X}; \Lambda) + \log \left[\frac{1}{N} \sum_{j=1, j \neq i}^N \exp \left[g_j(\mathbf{X}; \Lambda) \eta \right] \right]^{\frac{1}{\eta}}$$

【수학식 4】

<22> 여기에서, η 는 양의 상수이고 N 은 N -best 오인식 클래스들의 개수이다. 클래스 i 에 해당하는 음성 X 에 대해, $d_i(\mathbf{X}) > 0$ 는 오인식을 의미하며 $d_i(\mathbf{X}) \leq 0$ 는 정확한 인식을 의미한다.

<23> 완전한 손실함수는 부드러운 이진 손실함수의 형태로서 오인식 척도에 관하여 정의된다.

<24>

$$l_i(\mathbf{X}; \Lambda) = l(d(\mathbf{X}; \Lambda))$$

【수학식 5】

<25> 부드러운 이진 손실함수는 임의의 연속적인 이진 함수로 정의될 수 있으나 보통 다음과 같은 S형(sigmoid) 함수가 사용된다.

<26>

$$l(d) = \frac{1}{1 + \exp[-rd + \theta]}$$

【수학식 6】

<27> 여기에서, θ 는 영 또는 영보다 다소 작은 값으로 설정되고 r 은 상수값이다.



<28> 마지막으로, 미지의 음성에 대하여 인식기 성능은 평균 손실함수로서 평가된다.

<29>

$$l(\mathbf{X}; \Lambda) = \sum_{i=1}^M l_i(\mathbf{X}; \Lambda) 1(\mathbf{X} \in C_i)$$

【수학식 7】

<30> 여기에서, $1(\cdot)$ 는 표시자(indicator) 함수이다.

<31> 최적의 모델 파라미터는 평균 손실을 최소로 하는 모델 파라미터이며 평균 손실을 최소화하기 위해서 GPD 알고리즘이 주로 사용된다. GPD 알고리즘은 다음과 같이 주어진다.

<32>

$$\Lambda_{n+1} = \Lambda_n - \varepsilon_n \mathbf{U}_n \nabla l(\mathbf{X}; \Lambda) |_{\Lambda=\Lambda_n}$$

【수학식 8】

<33> 여기에서, \mathbf{U} 는 양으로 정의된 행렬, ε_n 는 학습 비율 또는 조절의 스텝 크기(step size)이고, Λ_n 는 시각 n 에서 모델 파라미터 세트이다.

<34> GPD 알고리즘은 제한 조건이 없는 최적화 기술이다. 그러나, 확률 모델로서의 HMM 구조를 유지하기 위해서는 어떠한 제약 조건이 주어져야만 한다. 복잡한 제약조건을 갖는 GPD 알고리즘을 사용하는 대신에 GPD 알고리즘을 변환된 HMM 파라미터에 적용하였다. 파라미터 변환 과정은 변환된 공간에서 어떠한 제약조건이 없으며 원시 공간으로의 변환시 HMM 제약조건이 만족되어야 한다. 다음과 같은 HMM 파라미터에 대한 제약조건이 원시 공간에서 유지되어야 한다.

<35>

$$\sum_j a_{ij} = 1 \text{ and } a_{ij} \geq 0, \sum_k c_{jk} = 1 \text{ and } c_{jk} \geq 0, \sigma_{jkl} \geq 0$$

【수학식 9】

<36> 상술한 식과 같은 원시 공간에서의 파라미터 제약 조건을 만족시키기 위해서 다음 식과 같은 파라미터 변환 과정이 파라미터 훈련 전후에 사용된다.

<37>

$$\begin{aligned}
 a_{ij} &\rightarrow \tilde{a}_{ij} \quad \text{where } a_{ij} = e^{\tilde{a}_{ij}} / \left(\sum_k e^{\tilde{a}_{ik}} \right) \\
 c_{jk} &\rightarrow \tilde{c}_{jk} \quad \text{where } c_{jk} = e^{\tilde{c}_{jk}} / \left(\sum_k e^{\tilde{c}_{jk}} \right) \\
 \mu_{jkl} &\rightarrow \tilde{\mu}_{jkl} = \mu_{jkl} / \sigma_{jkl} \\
 \sigma_{jkl} &\rightarrow \tilde{\sigma}_{jkl} = \log \sigma_{jkl}
 \end{aligned}$$

【수학식 10】

<38>

그러나, 세그멘탈(segmental) GPD 알고리즘에 기반한 MCE 훈련은 훈련 클래스에 의한 최적 상태열을 구하는 과정과 HMM을 구성하는 파라미터에 대한 경도 계산이 요구되며, 특히, 상태 확률 보정 방법은 훈련 데이터에 대한 과적응이 되어 훈련 데이터 및 인식 데이터에 대하여 일관되게 음성 인식 성능 향상을 도모하기가 어려운 문제점이 있다.

【발명이 이루고자 하는 기술적 과제】

<39>

상기 문제점을 해결하기 위하여 안출된 본 발명은, 훈련 데이터에 대한 인식 오류를 감소시키기 위하여 음성 인식 단위 집합을 구성하는 각각의 HMM의 상태에 대응하는 가중치를 도입하고 이를 훈련하는 과정에 있어서 발생하는 훈련 데이터에 대한 과적응 문제를 해결하기 위해서 확장된 손실 함수를 도입하여 상태 가중치를 훈련함으로써 훈련 데이터에 대한 과적응 문제를 완화시킴으로써 훈련 데이터 및 인식 데이터에 대한 음성 인식 성능 향상을 도모할 수 있는 상태 확률 보정 방법을 제공하는데 그 목적이 있다.

【발명의 구성 및 작용】

- <40> 상기 목적을 달성하기 위하여 본 발명의 상태 확률 보정 방법은, 분별함수를 통하여 입력되는 음성의 패턴을 인식하는 단계; 입력 음성에 대하여 클래스를 결정하는 단계; 상기 클래스의 결정에 따른 음성 인식 성능을 나타내는 평균손실함수를 획득하는 단계; 상기 평균손실함수에 의해 모델 파라미터식을 도출하는 단계; 및 상기 모델 파라미터 식에 따라 상태 가중치 훈련을 수행하는 단계를 포함하고, 상기 분별함수는 각 클래스에서 시간에 대한 최적 상태의 가중치를 상기 분별함수 내 확률 밀도 성분에 적용하는 것을 특징으로 한다.
- <41> 이하, 본 발명이 속하는 기술분야에서 통상의 지식을 가진 자가 본 발명의 기술적 사상을 용이하게 실시할 수 있을 정도로 상세히 설명하기 위하여 본 발명의 가장 바람직한 실시예들을 첨부된 도면을 참조하여 설명하기로 한다.
- <42> 도 1은 본 발명의 일 실시예에 의한 상태 확률 보정 방법을 나타낸 동작흐름도로서, 이러한 본 발명의 상태 확률 보정 방법에 관하여 설명하면 다음과 같다.
- <43> 먼저, 분별함수를 통하여 입력되는 음성의 패턴을 인식한다(S110). 여기서, HMM 상태 출력 확률에 내재해 있는 구별되는 정보를 이용하기 위해서 각 상태는 가중치를 갖게 되며 각 상태 출력 스코어는 상태 출력 확률값과 상태 가중치의 곱으로 표현된다. 기본적인 음성 인식 단위로서 M개의 HMM을 가지고 있고 개개의 인식 단위는 J개의 상태로 구성된다고 가정하자. 기본 인식 단위로는 보통 음소 또는 단어 모델이 사용된다. 또한, 전통적인 HMM에서는 클래스 i에 대한 분별함수가 수학식 1에 의해 정의되는 것과 유사하게 상태 가중 HMM에서 클래스 i에 대한 상기 분별함수는 다음 수학식에 의해 정의된다.

<44>

$$g_i(\mathbf{X}; \Lambda) = \sum_{t=1}^T \left[\log a_{\bar{q}_{t-1}\bar{q}_t}^{(i)} + w_{\bar{q}_t}^{(i)} \log b_{\bar{q}_t}^{(i)}(\mathbf{x}_t) \right] + \log \pi_{\bar{q}_0}^{(i)}$$

【수학식 11】

<45>

여기에서, $w_{\bar{q}_t}^{(i)}$ 는 클래스 i에서 시간 t에 대한 최적 상태의 가중치이다.

<46>

그 후, 입력 음성에 대하여 클래스 결정규칙을 적용한다(S120). 즉, 입력 음성 또는 관측벡터열에 대해 클래스를 결정한다.

<47>

그 후, 상기 클래스의 오인식에 따라 음성 인식 성능을 나타내는 평균손실함수를 획득한다(S130).

<48>

그 후, 상기 평균손실함수에 의해 모델 파라미터식을 도출한다(S140). 즉, 초기값 1로 설정된 상태 가중치의 훈련은 앞에서 언급된 수학식 4~수학식 8과 동일한 과정을 통해 다음과 같은 상기 모델 파라미터식으로 표현된다.

<49>

$$w_j^{(i)}(n+1) = w_j^{(i)}(n) - \varepsilon_n \frac{\partial}{\partial w_j^{(i)}} l(\mathbf{X}; \Lambda) \Big|_{w_j^{(i)} = w_j^{(i)}(n)}$$

【수학식 12】

<50>

수학식 9와 유사하게, 상태 가중치에 대한 제약조건은 원시 공간에서 성립되어야 한다. 즉, 음성 인식 단위 내의 상태 가중치는 하기 식에 의하여 제약되어야 한다.

<51>

$$\sum_{j=1}^J w_j = J, \quad 0 < w_j < J$$

【수학식 13】

<52> 여기에서, w_j 는 기본 인식 단위인 HMM 내의 상태 j 에 대한 상태 가중치이고 J 는 인식 단위 내의 상태의 총 개수이다.

<53> 끝으로, 상기 모델 파라미터 식에 따라 상태 가중치 훈련을 수행하고(S150), 상기 상태 가중치 훈련 전후에 파라미터 변환을 수행하는데, 상기 파라미터 변환은 다음 식에 의해 주어진다.

<54>

$$w_j \rightarrow \tilde{w}_j \quad \text{where } w_j = e^{\tilde{w}_j} / \left(\sum_k e^{\tilde{w}_k} \right)$$

【수학식 14】

<55> 여기에서, \tilde{w}_j 는 w_j 의 변환된 파라미터 공간에서의 상태 가중치이다.

<56> 또한, 상태 가중치의 훈련의 초기값은 1로 설정될 수 있다.

<57> 일반적으로, MCE 훈련에서는 오인식된 음성을 이용하여 파라미터 적응 훈련을 하므로 MCE 훈련에 사용되는 즉, 오인식되는 훈련 데이터의 양이 너무 적다면 훈련 데이터에 대한 과적응 문제가 발생하게 되어 훈련 데이터와 인식 데이터 사이에 인식 성능의 차이가 발생하게 된다. 따라서, 이러한 훈련 데이터와 인식 데이터의 인식 성능 차이를 극복하기 위한 방법이 요구되며 이를 위해서 부드러운 이진 손실 함수를 대신하여 대체 손실 함수를 고려한다. 이를 위해 오인식 척도를 구하는 과정에서 훈련 음성의 스트링 모델의 확률값에 가중치를 두어 오인식 척도에 더함으로써 오인식 척도를 확장하고 이를 확장된 선형 손실 함수로 선택할 수 있으며, 이러한 확장된 오인식 척도를 S형(sigmoid) 함수에 대입함으로써 S형(sigmoid) 이진 손실 함수를 선택할 수 있다. 훈련 음성의 스트링의 확률값에 가중치를 주어 더해주는 오인식 척도에 대한 확장은 다음 아래의 식과 같이 정의된다.

<58>

$$d_i(\mathbf{X}; \Lambda) = -g_i(\mathbf{X}; \Lambda) + \log \left[\frac{1}{N} \sum_{j=1, j \neq i}^N \exp[g_j(\mathbf{X}; \Lambda)\eta] \right]^{\frac{1}{\eta}}$$

$$\tilde{d}_i(\mathbf{X}; \Lambda) = d_i(\mathbf{X}; \Lambda) - k \cdot g_i(\mathbf{X}; \Lambda)$$

$$= -(1+k) \cdot g_i(\mathbf{X}; \Lambda) + \log \left[\frac{1}{N} \sum_{j=1, j \neq i}^N \exp[g_j(\mathbf{X}; \Lambda)\eta] \right]^{\frac{1}{\eta}}$$

【수학식 15】

<59>

여기에서, k는 추가로 더해주는 확률값의 계수이고 훈련 데이터에 대한 인식 오류를 증가시켜 주고 훈련 음성의 스트링 모델에 대한 확률값의 HMM 파라미터에 대한 미분값을 증가시켜 주는 효과가 있다.

<60>

HMM의 상태 확률 보정을 통한 음성 인식의 성능 향상을 평가하기 위하여 단독 숫자음을 이용한 실험을 실시하였다. 단독 숫자음 DB는 조용한 사무실 환경에서 녹음되었으며 500명(남성 250명, 여성 250명)의 음성으로 구성되었고, 400명(남성 200명, 여성 200명)의 음성이 훈련에 사용되었고 100명(남성 50명, 여성 50명)의 음성이 인식에 사용되었다. 본 실험에서는 11.025KHz DSP 보드 상에서의 음성 인식기 구현을 위해서 16KHz로 샘플링된 음성을 11.025KHz로 다운 샘플링하였다. 특징 벡터로는 log 에너지를 포함하여 13차 cepstral 계수, 13차 1차 미분계수, 13차 2차 미분 계수를 이용하여 총 3스트림, 39차 특징 벡터를 구성하였다. 모든 상태 출력 확률 분포는 8 믹스처(mixture) 다변수 가우시안 분포를 사용하였다. 베이스 라인 실험으로써 ML 훈련 방법에 의해서 3개의 상태, 3개의 스트림, 8개의 믹스처(mixture)로 구성된 모델을 생성하였다. HMM 가중치를 훈련하는 과정에서 오인식 척도를 계산하기 위해 3개의 가장 경쟁적인 스트링을 사용하였다(N=3).

<61> 본 실험에서는 4가지의 손실 함수(오인식 척도에 기인한 이진 손실 함수, 확장된 오인식 척도에 기인한 이진 손실 함수, 오인식 척도, 확장된 오인식 척도)를 사용하여 HMM 기본 파라미터를 MCE 훈련하여 인식 실험을 실시하였다. 하기 표 1은 훈련 데이터 인식률이 최대가 되었을 경우 훈련 및 인식 데이터에 대한 단어 인식률을 나타낸 것이다. 훈련을 반복함에 따라 훈련 데이터 인식률은 점차적으로 증가하나 인식 데이터에 대한 인식률은 거의 변화가 없는데, 이는 셉트럴(cepstral) 계수에 대한 상태 확률 분포가 훈련 데이터에 과적응 되어가는 과정임을 의미한다.

<62> 【표 1】

Data	MLE	SIG	WL+SIG	LIN	WL+LIN
Training	98.40	98.58	98.58	98.58	98.71
Testing	98.00	98.00	98.00	98.00	98.00

SIG : sigmoid loss function, LIN : linear loss function

WL : weighted likelihood of correct class

<63> HMM 기반의 음성 인식기에서 HMM 상태 가중치를 훈련한 음향 모델링의 성능 평가를 위해서 앞에서 언급된 4가지 손실 함수를 사용하여 반복하여 훈련함에 따른 인식 성능의 변화를 비교 평가하였다. 훈련 과정에서, 확률 모델로서의 HMM 구조를 유지하기 위해서 파라미터 변환 과정을 통해서 상태 가중치를 조절해 주었다. 하기 표 2는 인식 데이터에 대한 단어 인식률이 최대가 되었을 경우, 훈련 데이터 및 인식 데이터에 대한 인식률을 나타낸다.

<64> 【표 2】

Data	MLE	SIG	WL+SIG	LIN	WL+LIN
Training	98.40	98.54	98.54	98.44	98.56
Testing	98.00	98.17	98.58	98.00	98.50

<65> 도 2는 S형(sigmoid) 손실 함수를 사용하여 반복하여 훈련함에 따른 훈련 및 인식 데이터의 인식률 변화를 보여준다. 훈련을 반복함에 따라 초반에는 훈련 데이터의 인식률이 증가하는 경향을 보이나 MCE 훈련에 사용되는 훈련 데이터에 대한 과적응으로 인하여 인식률의 감소가 초래됨을 보여준다. 도 3은 $k=0.005$ 인 경우에 훈련 음성에 대한 훈련 음소열의 확률값에 가중치를 두어 확장된 오인식 척도를 구하고 이로부터 S형(sigmoid) 손실 함수를 구하여 훈련함에 따른 인식률의 변화를 보여준다. 반복함에 따라 훈련 데이터의 인식률 감소와 더불어 인식 데이터 인식률이 진동함을 볼 수 있다.

<66> 도 4는 $k=0$ 인 경우의 선형 손실 함수를 사용하여 상태 가중치를 훈련한 결과는 훈련 데이터 및 인식 데이터에 대해서 일관성 있는 인식 성능 향상을 보여주지 못함을 나타낸다. 도 5는 $k=0.005$ 인 경우의 훈련 음성에 대한 훈련 음소열의 확률값에 가중치를 주어 얻어진 확장된 선형 손실 함수를 사용하여 훈련한 결과는 훈련 데이터는 물론 인식 데이터에 대하여도 일관된 인식 성능 향상을 보여줌을 나타낸다.

<67> 선형 손실 함수에서 훈련 음소열 모델의 확률값에 곱하는 가중치에 따른 훈련 데이터와 인식 데이터의 인식률 변화를 실험하였을 때, 인식 데이터에 대한 인식률이 최대가 되었을 경우의 인식 결과는 다음 표 3과 같다.

<68> 【표 3】

k	0.001	0.002	0.003	0.004	0.005
Training	98.54	98.63	98.48	98.67	98.56
Testing	98.17	98.25	98.25	98.25	98.50

<69> 훈련 음성에 대한 훈련 음소열 모델의 확률값에 가중치 k 를 주어 오인식 척도에 더한 확장된 오인식 척도를 사용하는 것은 훈련 데이터에 대한 인식 오류를 증가시켜주는 효과를 가져오며, 아울러 상태 가중치에 대한 선형 손실 함수의 미분값을 $(1+k)$ 배 만큼 증가시켜 주는 효과가 있다. 따라서, k 값을 적절히 조절해 줌으로써 훈련 데이터와 인식 데이터 인식률이 일관되게 향상되는 결과를 얻을 수가 있다.

<70> 이상에서 설명한 본 발명은, 본 발명이 속하는 기술분야에서 통상의 지식을 가진 자에 있어 본 발명의 기술적 사상을 벗어나지 않는 범위 내에서 여러 가지로 치환, 변형 및 변경이 가능하므로 전술한 실시예 및 첨부된 도면에 한정되는 것이 아니다.

【발명의 효과】

<71> HMM 기반의 음성 인식 시스템에서 훈련 음성에 대한 훈련 음소열의 확률값에 가중치를 주어 얻어진 확장된 선형 손실 함수를 사용하여 HMM 상태 가중치를 훈련함으로써 훈련 및 음성 데이터에 대한 인식 성능이 일관성 있게 증가할 수 있도록 하는 장점이 있다.



【특허청구범위】

【청구항 1】

분별함수를 통하여 입력되는 음성의 패턴을 인식하는 단계;

입력 음성에 대하여 클래스를 결정하는 단계;

상기 클래스의 결정에 따른 음성 인식 성능을 나타내는 평균손실함수를 획득하는 단계;

상기 평균손실함수에 의해 모델 파라미터식을 도출하는 단계; 및

상기 모델 파라미터 식에 따라 상태 가중치 훈련을 수행하는 단계

를 포함하고,

상기 분별함수는 각 클래스에서 시간에 대한 최적 상태의 가중치를 상기 분별함수 내 확률 밀도 성분에 적용하는

것을 특징으로 하는 상태 확률 보정 방법.

【청구항 2】

제1항에 있어서,

상기 클래스의 결정에 따른 음성 인식 성능을 나타내는 평균손실함수를 획득하는 단계는,

훈련 음성의 스트링의 확률값에 가중치를 주어 오인식 척도를 더해서 획득된 확장된 오인식 척도를 사용하는

것을 특징으로 하는 상태 확률 보정 방법.

【청구항 3】

제1항에 있어서,

상기 상태 가중치의 훈련의 초기값은 1로 설정되는

것을 특징으로 하는 상태 확률 보정 방법.

【청구항 4】

제3항에 있어서,

상기 모델 파라미터식은, GPD 알고리즘에 의하여 주어지는

것을 특징으로 하는 상태 확률 보정 방법.

【청구항 5】

제4항에 있어서,

음소 또는 단어인 음성 인식 단위 내의 상기 상태 가중치는 원시 공간에서 성립되는 제약 조건을 가지는

것을 특징으로 하는 상태 확률 보정 방법.

【청구항 6】

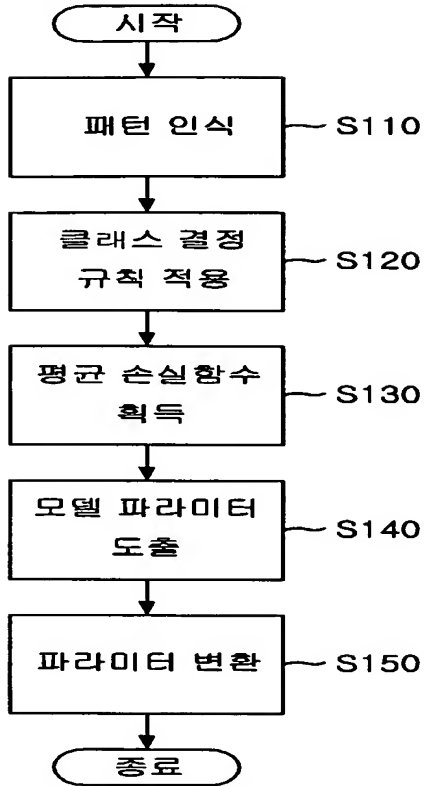
제3항에 있어서,

상기 모델 파라미터 식에 의한 파라미터 변환은 상기 상태 가중치의 훈련 전후에 수행되는


것을 특징으로 하는 상태 확률 보정 방법.

【도면】


【도 1】




【도 2】



【도 3】



【도 4】



【도 5】

